

Day-Ahead-Engpassprognose für elektrische Verteilnetze mittels probabilistischer Lastflussrechnung

Finn Nußbaum (*), Jonas Kock am Brink, Anna-Lena Steen, Christian Becker

Institut für Elektrische Energietechnik – Technische Universität Hamburg,
Harburger Schloßstraße 36, D-21079 Hamburg, Tel: +49 40 42878 3213,
{finn.nussbaum, anna-lena.steen, c.becker}@tuhh.de, <https://www.tuhh.de/ieet>

Kurzfassung: Die Transformation zur CO₂-Neutralität verursacht grundsätzliche Veränderungen unseres Energiesystems. Auf der einen Seite wird Energie zunehmend dezentral aus erneuerbaren und damit volatilen Quellen bereitgestellt, auf der anderen Seite steigen die Lasten durch Elektrifizierung und Sektorenkopplung. Diese Entwicklungen werden zu einer Zunahme von Netzengpässen im Verteilnetz führen. Eine deterministische Prognose dieser Netzengpässe ist aufgrund der Unsicherheiten bei der Vorhersage der erneuerbaren Erzeugung und des Lastverhaltens schwierig. Eine Berücksichtigung der Unsicherheiten bei der Engpassprognose bietet dagegen die Möglichkeit, neben der erwarteten Netzauslastung auch die Zuverlässigkeit der Prognose zu quantifizieren. Dazu wird eine Methodik entwickelt, die mittels einer probabilistischen Prognose die Betriebsmittelauslastung inklusive einer möglichen Spannbreite für den Folgetag vorhersagt. Dies geschieht mittels einer probabilistischen Lastflussrechnung nach der Monte-Carlo-Methode. Die notwendigen Eingangsverteilungen für Last und Erzeugung werden dabei auf Basis von historischen Lastdaten sowie numerischer Wetterprognosen erstellt. Es wird für ein ländliches und ein städtisches Mittelspannungsnetz nachgewiesen, dass mit Hilfe des Verfahrens die Betriebsmittelauslastung gut vorhergesagt werden kann. Allerdings bilden sich die hohen Unsicherheiten der Wettervorhersage auch in der Auslastungsprognose ab. Zusätzlich wird eine übersichtliche Darstellungsmethode zur Engpassauswertung vorgeschlagen.

Keywords: Verteilnetz, Engpassprognose, Probabilistische Lastflussrechnung, Präventives Engpassmanagement

1 Einleitung

Vor dem Hintergrund des Pariser Klimaabkommens und der damit verbundenen CO₂-Einsparungsziele befindet sich unser Energiesystem in einer grundlegenden Transformation. Im Rahmen der Energiewende wird auf der einen Seite Energie zunehmend dezentral durch erneuerbare Energieerzeugung wie Photovoltaik oder Windkraft bereitgestellt, auf der anderen Seite steigen die Lasten durch die Elektrifizierung weiterer Sektoren, z. B. durch Wärmepumpen oder E-Fahrzeuge. Diese Entwicklungen stellen insbesondere die elektrischen Verteilnetze vor große Herausforderungen, für die diese nicht ausgelegt sind: Waren sie bisher im Wesentlichen für den Transport der Energie zum Endverbraucher zuständig, werden sie durch die Anbindung der erneuerbaren Erzeugung in der Nieder- und Mittelspannung zunehmend bidirektional. Damit einhergehend werden Netzengpässe in den Verteilnetzen zunehmen [1]. Daher werden entsprechende Verfahren zur Engpassprognose, -erkennung und -behandlung im Verteilnetz notwendig [2].

Prinzipiell lassen sich diese Verfahren in zwei Kategorien einteilen: Präventive Verfahren haben das Ziel, Engpässe vorherzusagen und bereits vor dem Eintreten zu lösen. Kurative Maßnahmen dagegen werden erst ergriffen, wenn ein Engpass akut vorliegt und messtechnisch erkannt wird. Diese Eingriffe haben in der Regel Entschädigungszahlungen zur Folge und stellen für Endverbraucher einen spürbaren, unplanbaren Eingriff dar. Präventive Maßnahmen mit ausreichendem Vorlauf ermöglichen es hingegen, die notwendigen Verschiebungen von Leistung bereits bei der Energiebeschaffung zu berücksichtigen. [3]

Präventives Engpassmanagement ist auf zuverlässige Prognosen der Netzbelastung angewiesen. Aufgrund der stochastischen Natur des Wetters und des Nutzerverhaltens weisen Vorhersagen für die Netzbelastung jedoch Unsicherheiten auf. Daher ist es sinnvoll, nicht nur eine Auslastung vorherzusagen, sondern auch die Unsicherheiten zu quantifizieren [4]. So lassen sich Wahrscheinlichkeiten für die möglichen Szenarien angeben und Maßnahmen zielgerichtet auswählen.

1.1 Aktueller Forschungsstand

Der Einfluss des zunehmenden Anteils an erneuerbaren Energien in der Stromversorgung und der Veränderung der Lasten auf das präventive Engpassmanagement spiegelt sich in diversen Forschungsarbeiten wider. Es gibt bereits mehrere Ansätze zur präventiven Vermeidung von Engpässen im Verteilnetz, welche sich mit der Verschiebung flexibler Lasten befassen. Beispiele hierfür sind Flexibilitätsmärkte [5], die vortägliche Koordinierung von Leistungsfahrplänen [1] sowie die Nutzung angepasster Preissignale im Fall erwarteter Engpässe [6], [7]. Für Letzteres wird in [7] ein Framework zur Einbindung flexibler Prosumer mit E-Fahrzeugen und PV-Anlagen vorgeschlagen. Hierbei werden Leistungsfahrpläne der Prosumer in einem iterativen Verfahren ermittelt, indem der Verteilnetzbetreiber die geplanten Leistungsfahrpläne auswertet und im Fall von erwarteten Engpässen angepasste Preissignale übermittelt.

Für die genannten Ansätze ist stets eine Auswertung des erwarteten Netzzustandes im Hinblick auf Engpässe erforderlich. Dazu werden neben direkten Informationen der Verbraucher Prognosen für Lasten und Einspeisung benötigt. Um die Unsicherheiten des Lastverhaltens und der Einspeisung dargebotsabhängiger Erzeuger bei der Prognose zu berücksichtigen, eignen sich probabilistische Verfahren, welche zunehmend das Interesse von Netzbetreibern wecken [8]. In [9] werden zur Vorhersage der Residuallast im Verteilnetz probabilistische Modelle, die auf rekurrenten neuronalen Netzen basieren und mit einer geringen Anzahl an Messdaten auskommen, vorgeschlagen. Dadurch wird auch die für das Verteilnetz deutlich geringere Verfügbarkeit von Messdaten adressiert. In [10] wird die Anpassung von Ladefahrplänen von E-Fahrzeugen für die präventive Vermeidung von Engpässen vorgeschlagen, wobei zur probabilistischen Vorhersage der Erzeugung von PV-Anlagen eine Quantilsregression verwendet wird.

Für die Analyse von möglichen Engpässen werden aus den Last- und Erzeugungsprognosen Engpassprognosen erstellt. Da sie die Unsicherheiten inhärent berücksichtigen, werden zunehmend probabilistische Lastflussrechnungen eingesetzt. In [11] findet sich eine Übersicht von Modellen zur probabilistischen Lastflussrechnung speziell für die Anwendung in Netzen mit PV-Anlagen und E-Fahrzeugen. In [12] wird ein Engpassmanagementsystem, welches die Prognoseunsicherheiten der Erzeugung von Wind- und PV-Anlagen sowie der Lasten inklusive E-Fahrzeugen anhand probabilistischer Lastflussrechnungen berücksichtigt, entwickelt. Die

Lösung erfolgt anhand der Point-Estimate-Methode. Als Ergebnisse werden Leitungsbelastungen und Spannungsbeträge als kumulative Verteilungsfunktionen ermittelt. In [13] wird ein Framework zur Vorhersage von Engpässen anhand probabilistischer Lastflussrechnung mittels Monte-Carlo entwickelt. Hierfür wird der Leistungsbedarf für E-Fahrzeuge modelliert und die Prognosedaten für konventionelle Lasten und die Einspeisung von PV-Anlagen als zur Verfügung stehende Eingangswerte angenommen. Zur Visualisierung der erwarteten Engpässe werden Plots, welche die kumulative Wahrscheinlichkeit abbilden, vorgeschlagen. Die probabilistische Lastflussrechnung mittels Monte-Carlo wird auch in [2] im Rahmen der Entwicklung eines Engpassvorhersagetools genutzt. Die Darstellung der Engpässe anhand kumulativer Wahrscheinlichkeiten wird hierbei um die Nutzung von Konturplots erweitert. Ein weiterer Fokus wird auf die Modellierung der Prognose der Lasten und der Einspeisung von PV-Anlagen gelegt. Prognoseunsicherheiten werden als feste Prozentwerte in Abhängigkeit von dem Prognosehorizont berücksichtigt.

Die Güte der Eingangsdaten, die Berücksichtigung ihrer Unsicherheit und die Verfügbarkeit aller notwendigen Informationen spielen eine entscheidende Rolle für die Qualität der ermittelten Engpassprognose. Die bisherigen Ansätze betrachten häufig nur bestimmte Teilgebiete, wie beispielsweise PV-Anlagen und E-Fahrzeuge. Des Weiteren werden kürzere Prognosehorizonte betrachtet, sodass eine Verwendung der Ergebnisse im Day-Ahead-Markt nicht möglich ist. Für die Modellierung der Unsicherheiten werden vor allem historische Daten verwendet. Eine Quantifizierung der Prognoseunsicherheiten wird in [4] aufgegriffen. Im Rahmen der vorliegenden Arbeit wird eine Methodik zur Vorhersage der Netzbelastung in der Mittelspannung unter Einbeziehung von erneuerbaren Energieanlagen entwickelt, wobei ein wesentlicher Fokus auf die Optimierung der benötigten Wetterinformationen gelegt wird.

1.2 Zielsetzung

Dieser Beitrag zeigt die Entwicklung einer Auslastungsprognose, die sowohl für die Last als auch die Erzeugung probabilistische Modelle verwendet und durch ihre Ausführung am Vortag eine Berücksichtigung bei der Energiebeschaffung ermöglicht. Dabei werden zur Modellierung der Eingangsverteilungen der erneuerbaren Erzeugung die Ensemble-Prognosen des Deutschen Wetterdienstes (DWD) [14] genutzt, anhand derer sich explizit die Unsicherheiten in der Wetterprognose quantifizieren lassen. Für die Eingangsverteilung der Lasten wird auf historische Daten zurückgegriffen. Mit diesen werden anschließend probabilistische Lastflussrechnungen mit der Monte-Carlo-Methode durchgeführt. Aus den Ergebnissen dieser Lastflussrechnungen werden daraufhin Vorhersagen für die Auslastungen der Betriebsmittel und mögliche Engpässe erstellt. Daraus ergibt sich für das Framework der grundsätzliche Aufbau in Abbildung 1.




Abbildung 1: Ablauf der Engpassprognose

Der Aufbau orientiert sich an diesem Ablauf: In Abschnitt 2 werden zunächst die Grundlagen einer probabilistischen Lastflussrechnung mittels Monte-Carlo vorgestellt, und in Abschnitt 3 wird die Erzeugung der notwendigen Eingangsverteilungen erläutert. In Abschnitt 4 werden die untersuchten Netze und Szenarien vorgestellt, bevor in Abschnitt 5 die Ergebnisse der probabilistischen Lastflussrechnung analysiert und Ansätze zur Engpassbestimmung vorgestellt werden. Abschließend werden die Untersuchungen in Abschnitt 6 zusammengefasst und ein Ausblick auf weitere Fragestellungen gegeben.

2 Probabilistische Lastflussrechnung mittels Monte-Carlo

Ein elektrisches Netz besteht aus einer bestimmten Anzahl an Knoten N , an denen jeweils Erzeugungen \underline{S}_{Gi} und Lasten \underline{S}_{Li} angeschlossen sind. Diese sind mittels Leitungen verbunden, die durch ihre Impedanzen charakterisiert sind. Unter Kenntnis der Netztopologie lässt sich mit den Leitungsimpedanzen bzw. -admittanzen die komplexe Knotenadmittanzmatrix \underline{Y}_k aufstellen. Mit dieser ergeben sich die Leistungsgleichungen für die einzelnen Knoten

$$\underline{S}_i = \underline{U}_i \sum_{j=1}^N \underline{Y}_{ij}^* \cdot \underline{U}_j^* \quad (1)$$

des Netzes. Bei bekannten Leistungen $\underline{S}_i = \underline{S}_{Gi} - \underline{S}_{Li}$ ergibt sich ein nichtlineares Gleichungssystem mit N Gleichungen der Form

$$0 = \underline{S}_i - \underline{U}_i \sum_{j=1}^N \underline{Y}_{ij}^* \cdot \underline{U}_j^*, \quad (2)$$

die beispielsweise mit dem Newton-Raphson-Algorithmus nach den Knotenspannungen gelöst werden können. Anhand der Knotenspannungen können anschließend die Leistungsflüsse und somit die Auslastungen der einzelnen Betriebsmittel bestimmt werden. Voraussetzung ist dabei die Kenntnis der Knotenleistungen, also der jeweils vorhandenen Einspeisungen $\underline{S}_{Gi} = P_{Gi} + j \cdot Q_{Gi}$ sowie der Lastabnahmen $\underline{S}_{Li} = P_{Li} + j \cdot Q_{Li}$.

Aufgrund der Unsicherheiten in der Vorhersage der Einspeisung der erneuerbaren Energieanlagen und des stochastischen Nutzerverhaltens liegen keine deterministischen Leistungswerte für den jeweiligen Zeitpunkt, sondern Wahrscheinlichkeitsverteilungen $S_{Gi}(\vec{x})$ und $S_{Li}(\vec{x})$ vor, die den Bereich zu erwartender Leistungen angeben. Diese hängen jeweils von verschiedenen Variablen \vec{x} wie den Wetterparametern Wind, Solarstrahlung oder Temperatur im Falle der Erzeugung oder der Jahreszeit und der Uhrzeit im Falle der Last ab. Mit diesen lassen sich keine deterministischen Lastflussrechnungen durchführen. Stattdessen müssen probabilistische Lastflussrechnungen durchgeführt werden, die in der Lage sind, Verteilungen als Eingangswerte zu verarbeiten. Hierfür existiert eine Reihe von Ansätzen, die sich auf sampling-basierte, analytische und approximierende Methoden aufteilen [15]. In diesem Framework wird eine sampling-basierte probabilistische Lastflussrechnung mittels Monte-Carlo (MC-PLF) gewählt. Im Rahmen der Monte-Carlo-Simulation werden für jeden Zeitschritt der Lastflussrechnung wiederholt zufällig Samples aus der Eingangsverteilung gezogen, sodass sich für die Leistungen Sets der Form $S_{Gi} = [S_{Gi1}, S_{Gi2}, \dots, S_{GiM}]$ bzw. $S_{Li} = [S_{Li1}, S_{Li2}, \dots, S_{LiM}]$ ergeben. Für eine ausreichend hohe Anzahl an Samples M konvergieren diese gegen die Eingangsverteilung.

lungen. Für jede der Eingangsleistungen aus den Sets kann anschließend eine deterministische Lastflussrechnung durchgeführt werden. Die Ergebnisse der einzelnen Berechnungen werden gesammelt und aus ihnen anschließend eine Verteilung ermittelt. Die MC-PLF ist einfach zu implementieren, im Gegensatz zu analytischen Verfahren robust gegenüber unterschiedlichen Verteilungen und nicht auf Linearisierungen der Netzgleichungen angewiesen [15]. Daher wird sie hier trotz des höheren Berechnungsaufwandes gewählt.

3 Eingangsverteilungen der probabilistischen Lastflussrechnung

Wie in Abschnitt 2 dargestellt, sind für die probabilistische Lastflussrechnung Eingangsverteilungen der Lasten und Einspeisungen an den Netzknoten notwendig. Für die Lasten werden diese aus historischen Daten gewonnen. Bei der Erzeugung wird ein indirekter Ansatz gewählt. Da in der Mittel- und Niederspannung vorrangig Erzeugung aus erneuerbaren Quellen vorhanden ist, werden die zugehörigen Wetterparameter der solaren Strahlung, der Temperatur und der Windgeschwindigkeit als Eingangsverteilungen modelliert und anschließend während der Lastflusssimulationen in entsprechende Leistungen umgerechnet. Im Folgenden werden die Verfahren zur Erzeugung der Eingangsverteilungen zunächst für das Wetter und anschließend für die Lasten dargestellt.

3.1 Probabilistische Wettermodelle

Zur Modellierung der Wetterparameter und ihrer Verteilung werden die Prognosen des Deutschen Wetterdienstes (DWD) verwendet. Dieser führt alle 3 Stunden Vorhersagen für die nächsten 48 Stunden durch und veröffentlicht die Ergebnisse auf seinem Datenportal [16]. Dort enthalten sind zum einen das Vorhersagemodells *ICON-D2*, das eine „Best-Effort“-Prognose in stündlicher Auflösung für Wind und Temperatur sowie in viertelstündlicher Auflösung für Strahlungswerte zur Verfügung stellt. Zum anderen berechnet der DWD sogenannte Ensemble-Prognosen im Modell *ICON-D2-EPS*. In diesen wird die deterministische Wetterprognose 20-mal mit leicht veränderten Anfangswerten wiederholt simuliert und als Simulations-Ensemble mit stündlichen Werten veröffentlicht. Diese beiden Prognosen für die Windgeschwindigkeit in einer Höhe von 127 Metern werden in Abbildung 2 dem realen Verlauf gegenübergestellt.

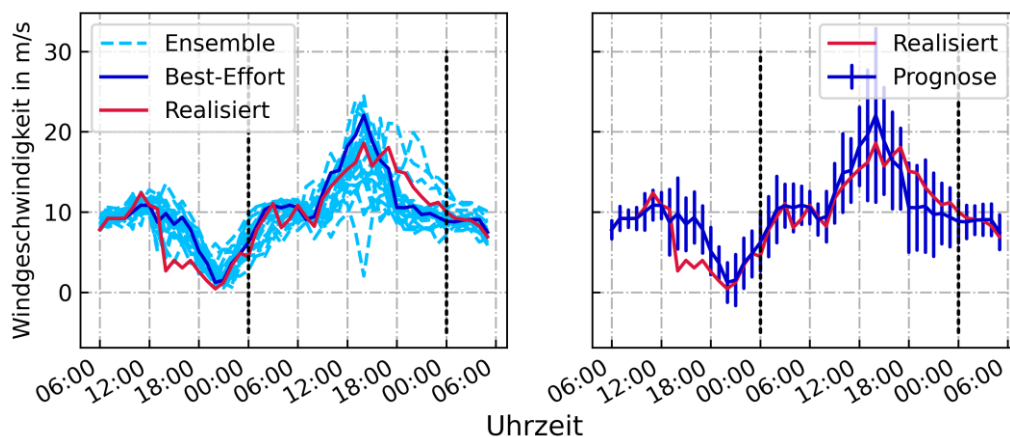


Abbildung 2: Vergleich der Ensemble-Prognosen und der Best-Effort-Prognose mit dem realen Verlauf basierend auf der 6 Uhr Vorhersage des 4. Juli 2023 für Hamburg

Auf der linken Seite der Abbildung ist zu sehen, dass die Ensemble-Mitglieder die Unsicherheit der Prognose abbilden. Auf der rechten Seite ist die „Best-Effort“-Prognose mit dem 2σ -Intervall der aus den Ensemble-Mitgliedern ermittelten Standardabweichung dem realen Verlauf gegenübergestellt. Auch hier zeigt sich, dass diese Standardabweichung die Prognoseunsicherheit quantifiziert. Dies motiviert die Kombination der beiden Prognose-Modelle zu einer Wahrscheinlichkeitsverteilung. So werden in der Folge Normalverteilungen $x_{WP} \sim \mathcal{N}(\mu_{BE}, \sigma_{Ens})$ für die einzelnen Wetterparameter x_{WP} angenommen. Diese besitzen Dichtefunktionen der Form

$$f_{t,xy}(x_{WP}) = \frac{1}{\sigma_{Ens,t,xy}\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu_{BE,t,xy}}{\sigma_{Ens,t,xy}}\right)^2} \quad (3)$$

mit dem „Best-Effort“-Wert als Mittelwert μ_{BE} und der aus der Ensembleprognose ermittelten Standardabweichung σ_{Ens} . Die Vorhersagen beider Modelle umfassen Deutschland und Umgebung, dafür wird der Bereich in Gitterzellen unterteilt. Der Mittelwert μ_{BE} sowie die Standardabweichung σ_{Ens} hängen entsprechend vom Zeitpunkt t und der Gitterzelle xy des Vorhersagemodells ab, daher ergeben sich für jede Zelle und jeden Zeitpunkt eigene Verteilungen. Im Rahmen des Samplings in der MC-PLF sind die Korrelationen der Wetterparameter untereinander sowie zwischen benachbarten Gitterzellen zu berücksichtigen. Die relevanten Korrelationen werden in den nächsten Abschnitten beschrieben und die jeweiligen Verteilungen erläutert. Zeitliche Kopplungen werden in dieser Methodik nicht betrachtet.

3.1.1 Eingangsverteilung für den Wind

Die Windgeschwindigkeit v in einer Höhe von 127 Metern, die zur Berechnung der Leistung der im Netz enthaltenen Windkraftanlagen verwendet wird, ist über die geographisch wenig ausgedehnten Verteilnetze (5-8 Zellen des *ICON-D2*-Gitters) sehr ähnlich. Für die betrachteten Netze im Raum Hamburg wird der Korrelationskoeffizient zwischen den Gitterzellen analysiert, der ein Maß für den Grad des linearen Zusammenhangs ist. Hier ergibt sich ein Wert von 0,9 und höher, was einen fast vollständig linearen Zusammenhang der Windgeschwindigkeiten bedeutet. Daher ist es in der MC-PLF nicht sinnvoll, für jede Zelle einzeln eine Windgeschwindigkeit zu sampeln. Stattdessen wird für alle Zellen eine Geschwindigkeit angenommen. Dabei werden der Mittelwert $\bar{\mu}_{BE}$ der „Best-Effort“-Prognosen und der Mittelwert $\bar{\sigma}_{Ens}$ der Standardabweichungen der Ensemble-Prognosen über die Gitterzellen verwendet. Um die geringe Abweichung zwischen den Zellen zu berücksichtigen, wird anschließend für jede Zelle ein normalverteilter Rauschterm addiert. Die Standardabweichung σ_{vr} dieses Rauschens ist aus historischen Messdaten ermittelt worden. So ergibt sich

$$v_{t,xy} \sim \mathcal{N}(\bar{\mu}_{BE,t}, \bar{\sigma}_{Ens,t}) + \mathcal{N}(\mu = 0, \sigma_{vr}) \quad (4)$$

für die Eingangsverteilung des Windes in Abhängigkeit der Zelle und des Zeitpunktes.

3.1.2 Eingangsverteilung für die Temperatur

Die Temperatur wird verwendet, um den temperaturabhängigen Wirkungsgrad der PV-Module bei der Berechnung der erzeugten Leistung zu berücksichtigen. In folgenden Untersuchungen ist geplant, auch die Lasten wie Wärmepumpen und ihre Temperaturabhängigkeit explizit zu modellieren. Ähnlich wie beim Wind ergeben sich über die räumliche Ausdehnung der Verteilnetze kaum Unterschiede in den Temperaturen. Für einen Zeitraum von 3 Monaten weichen

die Temperaturen in den Gitterzellen in 90 % der Fälle um weniger als 0,25 °C vom Mittelwert der Zellen ab. Daher wird auch bei der Temperatur mit dem Mittelwert $\bar{\mu}_{BE}$ der „Best-Effort“-Prognosen und dem Mittelwert $\bar{\sigma}_{Ens}$ der Standardabweichungen der Ensemble-Prognosen gerechnet. So ergibt sich eine Verteilung der Form

$$\vartheta_t \sim \mathcal{N}(\bar{\mu}_{BE,t}, \bar{\sigma}_{Ens,t}) \quad (5)$$

für die Temperatur in der ganzen Region, die Abhängigkeit von der Gitterzelle xy entfällt.

3.1.3 Eingangsverteilung für die solare Strahlung

Bei der solaren Strahlung, die zur Berechnung der PV-Leistung verwendet wird, liegen Prognosedaten für die direkte Strahlung E_{dir} und die diffuse Strahlung E_{diff} vor. Die Solarstrahlung ist im Gegensatz zu Temperatur und Windgeschwindigkeit stark ortsabhängig und zusätzlich sind die beiden Strahlungsparameter korreliert [4]. Eine Analyse für die betrachteten Netze zeigt, dass sie stark zwischen den Gitterzellen variiert. Anhand der Ensemble-Prognosen lassen sich Korrelationskoeffizienten im Bereich von -0,7 bis -0,9 nachweisen, was auf einen fast vollständig negativen linearen Zusammenhang hindeutet. Um dies beim Sampling zu berücksichtigen, werden die beiden Strahlungsparameter aus einer gemeinsamen, bivariaten Normalverteilung der Form

$$\vec{E}_{t,xy} = \begin{pmatrix} E_{dir,t,xy} \\ E_{diff,t,xy} \end{pmatrix} \sim \mathcal{N}_2(\vec{\mu}_{t,xy}, \Sigma_{t,xy}) \quad (6)$$

gezogen. Der Vektor $\vec{\mu}$ besteht dabei aus den beiden „Best-Effort“-Prognosen als Mittelwerte der beiden Einzelverteilungen. Die Kovarianzmatrix $\Sigma_{t,xy}$ hat die Form

$$\Sigma_{t,xy} = \begin{bmatrix} \sigma_{Ens,t,xy,dir}^2 & cov_{t,xy} \\ cov_{t,xy} & \sigma_{Ens,t,xy,diff}^2 \end{bmatrix} \quad (7)$$

mit den Varianzen der einzelnen Strahlungsparameter $\sigma_{Ens,t,xy,dir}^2$ und $\sigma_{Ens,t,xy,diff}^2$ in der jeweiligen Gitterzelle sowie der Kovarianz der jeweiligen Ensemble-Prognosen der Gitterzelle $cov_{t,xy}$.

3.2 Probabilistische Lastmodelle

Bei den Eingangsverteilungen für die Lasten wird nach drei Kategorien unterschieden, dies sind Haushalts-, Gewerbe- und Industrielasten. Für alle drei im Modell vorkommenden Typen werden aus historischen Daten probabilistische Profile erstellt. Dazu wird für die Haushaltsprofile ein Datensatz der HTW Berlin [17] genutzt. Für die Gewerbe- bzw. Industrieprofile werden die Datensätze aus [18] verwendet. Zur Erstellung von probabilistischen Profilen erfolgt eine Orientierung an den Standardlastprofilen [19]. Ähnlich wie bei diesen wird nach drei Jahreszeiten (Sommer, Winter, Übergangszeiträume) und nach Wochentagen (Mo-Fr, Sa, So) unterschieden. Für diese neun unterschiedlichen Verlaufstypen werden die in den Datensätzen enthaltenen Tage den Kategorien zugeordnet und aus allen in der jeweiligen Kategorie enthaltenen Tagen mittlere Lastwerte $\mu_{t,k}$ und Standardabweichungen $\sigma_{t,k}$ für die einzelnen 15-Minuten-Intervalle des Tages gebildet. Zuletzt werden die Profile normiert, um diese später auf die in den Netzdaten hinterlegten Verbrauchsleistungen anwenden zu können. Daraus resultieren normierte Normalverteilungen der Form

$$f_{t,k}(p_L) = \frac{1}{\sigma_{t,k}\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{p_L - \mu_{t,k}}{\sigma_{t,k}}\right)^2} \quad (8)$$

für die Lastleistungen p_L in den jeweiligen Kategorien k . Die sich ergebenden probabilistischen Tagesverläufe sind beispielhaft für die Haushaltslasten und den Übergangszeitraum in Abbildung 3 gestellt. Dabei ist der Mittelwert der probabilistischen Profile (schwarz) mit den Standardabweichungen (blaue Balken) für jedes 15-Minuten-Intervall des Tages dargestellt.




Abbildung 3: Probabilistische Lastprofile am Beispiel für Haushaltslasten im Übergangszeitraum

4 Untersuchte Mittelspannungsnetze

Für die Untersuchung der Zuverlässigkeit der Prognose und der anschließenden Engpassauswertung mittels der Ergebnisse des Frameworks werden zwei beispielhafte Mittelspannungsnetze des Simbench-Datensatzes [19] verwendet, ein urbanes und ein ländliches. Dabei wird jeweils das zweite Ausbauszenario für 2034 verwendet, sodass sich die in Tabelle 1 angegebenen Kennwerte für die Netze ergeben. Diese zeigt, dass das städtische Netz stark lastgetrieben ist, das ländliche Netz dagegen einen deutlichen Erzeugungsüberschuss aufweist.

Tabelle 1: Vergleich der Nennleistungen der untersuchten Mittelspannungsnetze

| Netztyp | Lasten MV | Lasten LV | PV-Erzeugung in MV | PV-Erzeugung in LV | WKA-Erzeugung |
|-----------|-----------|-----------|--------------------|--------------------|---------------|
| städtisch | 1,92 MW | 66,62 MW | 0 MW | 24,22 MW | 2,9 MW |
| ländlich | 2,11 MW | 25,88 MW | 1,26 MW | 28,98 MW | 16,79 MW |

In den Netzmodellen werden die Ortsnetztransformatoren ergänzt und hinter ihnen die Niederspannungsnetze aggregiert modelliert. Zusätzlich wird das Netzmodell um Einspeisemodelle ergänzt, welche die Wetterdaten in äquivalente Leistungseinspeisungen umrechnen. Für die PV-Anlagen wird dabei ein einfaches Modell verwendet, dass die effektive Solarstrahlung in die erzeugte Leistung umrechnet. Für Windkraftanlagen wird die Windgeschwindigkeit mittels einer normierten Leistungskennlinie in eine elektrische Leistung umgerechnet. Für beide Netze werden geographische Lagen im Großraum Hamburg angenommen. Mittels des entwickelten Frameworks werden jeweils Engpässe auf der Mittelspannungsebene untersucht. Dabei werden die Leitungsbelastungen in Bezug auf die maximal zulässigen Ströme, die Transformatorbelastungen in Bezug auf die zulässigen Leistungen und die Knotenspannungen in Bezug auf das Spannungsband betrachtet.

5 Ergebnisse

Zur Untersuchung der Zuverlässigkeit der Prognose werden Simulationen beider Netze für unterschiedliche Last- und Einspeisesituationen durchgeführt. Dabei werden mit dem 3. Januar 2023 ein Tag mit hohen Einspeiseleistungen aus Windkraftanlagen, geringer PV-Leistung und hohen Lasten sowie mit dem 5. Juli 2023 ein Tag mit hoher Einspeisung aus PV und Wind bei niedrigen Lasten gewählt. Als Eingangsdaten für die Erzeugung der probabilistischen Wettermodelle werden dabei die Wetterprognosen von 6 Uhr (UTC) des Vortages verwendet, so dass ein auf ihnen basierendes Engpassmanagement noch vor Day-Ahead-Schluss um 12 Uhr erfolgen könnte. Parallel dazu wird mit den tatsächlichen Lasten und Wetterparametern des gewählten Tages die realisierte Netzauslastung ermittelt. Die Ergebnisse der Prognose sind in Abbildung 4 für den 5. Juli 2023 im ländlichen Netz und in Abbildung 5 für den 3. Januar im städtischen Netz dargestellt. Die Abbildungen zeigen jeweils den Median der Prognose mit seinem 10-90%-Perzentil-Intervall (blau) sowie in rot den realisierten Verlauf. Dargestellt sind jeweils der am stärksten belastete Transformator und die am stärksten belastete Leitung.

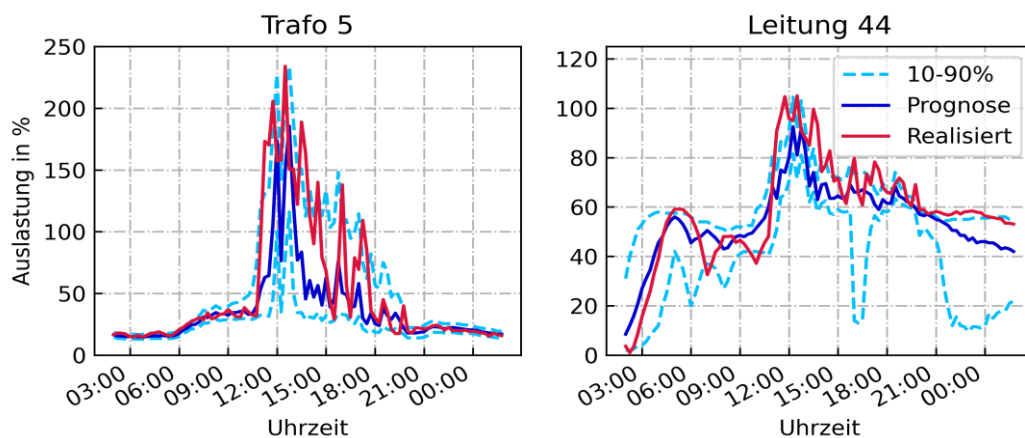


Abbildung 4: Auslastungsprognose für den 5. Juli 2023 im ländlichen Netz

Es zeigt sich, dass die Prognose mit dem Unsicherheitsband die realen Verläufe gut widerspiegelt. Im Szenario eines stark erneuerbar geprägten Netzes wie dem ländlichen Netz im Sommer (Abbildung 4) ergeben sich zu einigen Zeitpunkten große Perzentil-Intervalle durch die mit der Wetterprognose verbundenen Unsicherheiten.

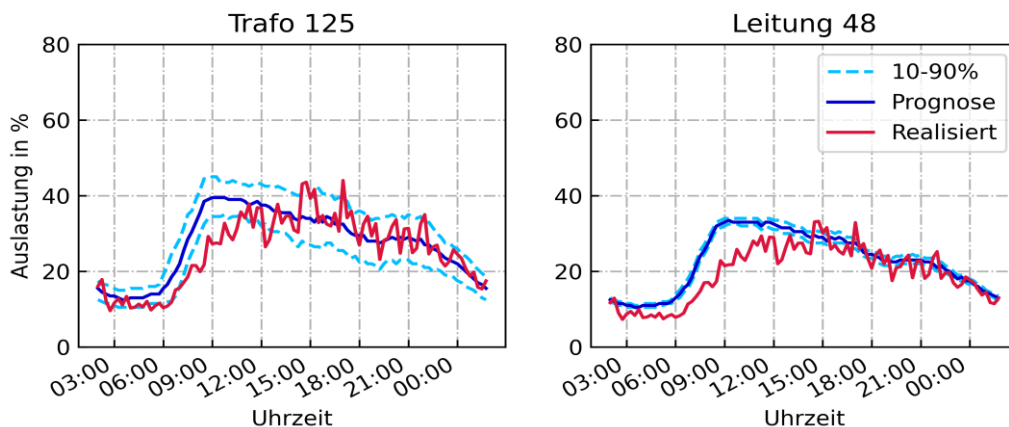


Abbildung 5: Auslastungsprognose für den 3. Januar 2024 im städtischen Netz

Im Vergleich zu einem lastgetriebenen Szenario wie dem städtischen Netz im Winter (Abbildung 5) zeigt sich der deutliche Einfluss des Wetters auf die Prognose. So ist die Median-Vorhersage in den last-dominierten Fällen näher am realen Verlauf und die Unsicherheiten sind geringer.

Zur Auswertung der Prognosegüte werden zwei Metriken verwendet: Zum einen wird für die Transformator- und Leitungsbelastungen sowie die Knotenspannungen die Abweichung des Medians der Prognose zu den realen Belastungen mittels des mittleren absoluten Fehlers (MAE) berechnet. Zum anderen wird betrachtet, wie häufig die realen Verläufe im Bereich zwischen dem 10 % und dem 90 %-Perzentil der Prognose enthalten sind. Beide Metriken werden dabei über den Prognose-Tag und die im Netz enthaltenen Betriebsmittel gemittelt. Für die beiden betrachteten Tage ergeben sich so die Werte in Tabelle 2. Beim MAE sind die Angaben für Transformatoren und Leitungen die Abweichungen in Prozentpunkten bei der Auslastung, die sich aus den Lastflussrechnungen bereits als Prozentwert ergibt.

Tabelle 2: Statistische Auswertung der Prognosegüte

| Datum | Netz | MAE in % | | MAE in p. u. | Perzentil-Score in % | | |
|------------|-----------|-----------------|-----------|--------------|----------------------|------------|-----------|
| | | Transformatoren | Leitungen | Spannungen | Transformatoren | Spannungen | Leitungen |
| 05.07.2023 | ländlich | 7,660 | 2,129 | 0,004 | 81,760 | 31,425 | 39,449 |
| | städtisch | 1,392 | 0,913 | 0,002 | 86,800 | 31,351 | 51,302 |
| 03.01.2024 | ländlich | 4,245 | 1,618 | 0,006 | 61,470 | 10,467 | 24,832 |
| | städtisch | 3,049 | 1,426 | 0,004 | 62,307 | 14,661 | 34,107 |

Die Ergebnisse zeigen, dass bereits die Median-Prognose den grundsätzlichen Verlauf der Auslastungen widerspiegeln. Die mittleren Abweichungen sind bei allen Betriebsmitteln gering. Allerdings zeigen die Perzentil-Scores auf, dass es Zeiten mit deutlichen Abweichungen, auch über das 10-90-%-Perzentil-Intervall hinaus, gibt. Die sehr geringen Werte beim Perzentil-Score der Leitungen und der Spannungen sind jedoch auch darauf zurückzuführen, dass die Perzentil-Intervalle hier sehr klein sind und daher bereits zahlenmäßig geringe Abweichungen zum Verlassen des Intervalls führen können.

Auf Basis der Prognosen können Aussagen zu Engpässen und ihrer Wahrscheinlichkeit getroffen werden. Die generell gute Übereinstimmung der Prognose mit den realen Verläufen ermöglicht es hier zunächst, Engpasssituationen zu identifizieren. Dabei sollte aufgrund der Prognoseunsicherheiten aber auf einen wahrscheinlichkeitsbasierten Ansatz zurückgegriffen werden, bei dem reagiert wird, wenn ein bestimmter Anteil der Samples einen Engpass aufweist. Um hier einfacher Entscheidungen treffen zu können, wird eine alternative Darstellungsform in einem Kontourplot, ähnlich wie in [2], gewählt. In diesem wird dargestellt, wie viele der Samples eine Auslastung innerhalb bestimmter Intervalle aufweisen. So lassen sich Engpässe und ihre Wahrscheinlichkeiten wie in Abbildung 6 schnell erkennen. Für die bereits zuvor gezeigte Leitung 44 im ländlichen Netz am 5. Juli 2023 besteht mittags mit hoher Wahrscheinlichkeit eine Überlastung. Diese ist auch im Kontourplot eindeutig erkennbar: Mittags um 13

Uhr weisen bis zu 800 der 1000 Samples eine Auslastung von mehr als 100 % auf und somit ist eine Überlastung fast sicher. Schwieriger sind die Grenzbereiche, in denen nur ein Teil der Samples einen Engpass vorhersagt. In diesen hilft der Kontourplot, indem er diese ins Verhältnis setzt und über den Verlauf der Farben das Eintrittsrisiko einer Überlastung angibt. Gegen 18 Uhr liegen beispielsweise 400-600 Samples bei einer Auslastung zwischen 60 % und 80 %. Ob und wann in einer solchen Situation einzugreifen ist, ist in weiteren Untersuchungen festzustellen.




Abbildung 6: Engpassvorhersage anhand Kontourplot für eine Leitung im ländlichen Netz am 5. Juli 2023

Generell zeigt sich bei der Untersuchung beider Netze, dass im städtischen Netz in der Mittelspannung selten Engpässe auftreten, lediglich die Ortsnetztransformatoren sind betroffen. Im ländlichen Netz sind es vor allem die Transformatoren, die von zum Teil erheblichen Engpässen betroffen sind. Allerdings sind auch in Szenarien mit starker Einspeisung aus Windenergie einige Leitungen betroffen, wie beispielhaft an der Leitung 44 zu sehen.

6 Fazit und Ausblick

Mit dem in diesem Paper vorgestellten Framework ist es möglich, Engpässe bereits am Vortag zu identifizieren. Die über die probabilistischen Lastflussrechnungen gewonnenen Perzentil-Intervalle beziehen die Unsicherheiten der Wetterprognose ein und ermöglichen es so, Engpasssituationen zu erfassen. Allerdings zeigt sich, dass sich gerade in stark durch erneuerbare Einspeisung geprägten Situationen große Perzentil-Intervalle ergeben. Ursächlich hierfür sind die Unsicherheiten der Wettervorhersage. In weiteren Untersuchungen ist zu prüfen, inwieweit die Perzentil-Intervalle durch die Verwendung anderer Eingangsverteilungen oder kürzerer Vorhersagehorizonte verkleinert und damit die Prognose verbessert werden können.

Die meisten Engpässe haben sich in den Simulationen nicht in der Mittelspannung, sondern an den Ortsnetztransformatoren und damit den unterlagerten Niederspannungsnetzen gezeigt. Daher ist es sinnvoll, zu untersuchen, inwiefern die hier vorgestellte Methodik auch auf die Niederspannung erweitert werden kann. Dazu ist es sinnvoll, die Lastmodelle explizit um weitere Elemente wie Wärmepumpen und E-Fahrzeuge zu erweitern und auf eine größere Datenbasis zu stellen.

Mit dem Kontourplot ist eine Möglichkeit vorgestellt, Engpasssituationen und ihre Wahrscheinlichkeiten schnell und übersichtlich darzustellen. Auf der Basis dieser Ergebnisse kann ein

probabilistisches Engpassmanagement entwickelt werden. Dazu müssen in einem ersten Schritt Eingriffsschwellen festgelegt werden, ab denen Maßnahmen bereits präventiv ergriffen werden sollten.

7 Danksagung

Diese Forschung wurde durch das Bundesministerium für Wirtschaft und Klimaschutz (BMWK) der Bundesrepublik Deutschland im Projekt „KoLa – Koordinierungsfunktion des Verteilnetzes und Lastmanagement für den elektrifizierten Personenverkehr“ unter der Projektnummer 01MV22005D gefördert.

8 Literatur

- [1] Netze BW GmbH, „flexQgrid - Praxisorientierte Umsetzung des quotenbasierten Netzampelkonzeptes zur Flexibilitätsnutzung im und aus dem Verteilnetz,“ 2023.
- [2] A. Srivastava, D. Steen, L. A. Tuan, O. Carlson, I. Bouloumpasis, Q.-T. Tran und L. Lemius, „Development of a DSO support tool for congestion forecast,“ *IET Generation, Transmission & Distribution*, 2021.
- [3] H. Schermeyer, Netzengpassmanagement in regenerativ geprägten Energiesystemen, Dissertation, Karlsruher Institut für Technologie, 2018.
- [4] Fraunhofer IEE und Deutscher Wetterdienst, „GRIDCAST - Erhöhung der Netzsicherheit durch flexibilisierte Wetter- und Leistungsprognosemodelle auf Basis stochastischer und physikalischer Hybridmethoden,“ 2022.
- [5] M. Pečjak, C. Fournely und E. Lakić, „A novel approach for flexibility trading in the distribution network,“ *IEEE 19th International Conference on the European Energy Market (EEM)*, 2023.
- [6] W. Liu, Q. Wu, F. Wen und J. Østergaard, „Day-Ahead Congestion Management in Distribution Systems Through Household Demand Response and Distribution Congestion Prices,“ *IEEE TRANSACTIONS ON SMART GRID*, VOL. 5, NO. 6, November 2014.
- [7] J. Hu, J. Wu, X. Ai und N. Liu, „Coordinated Energy Management of Prosumers in a Distribution System Considering Network Congestion,“ *IEEE TRANSACTIONS ON SMART GRID*, VOL. 12, NO. 1, Januar 2021.
- [8] S. E. Haupt, M. G. Casado, M. Davidson, J. Dobschinski, P. Du, Matthias, T. Miller, C. Möhrlein, A. Motley, R. Pestana und J. Zack, „The Use of Probabilistic Forecasts,“ *IEEE power & energy magazine*, 2019.
- [9] G. Gürses-Tran, H. Flamme und A. Monti, „Probabilistic Load Forecasting for Day-Ahead Congestion Mitigation,“ *International Conference on Probabilistic Methods Applied to Power Systems (PMAPS)*, 2020.

- [10] N. Brinkel, L. Visser, T. AlSkaif und W. v. Sark, „Avoiding Low-Voltage Grid Congestion using Smart Charging of Electric Vehicles based on Day-Ahead Probabilistic Photovoltaic Forecasts,“ *International Conference on Smart Energy Systems and Technologies (SEST)*, 2021.
- [11] U. H. Ramadhani, M. Shepero, J. Munkhammar, J. Widén und N. Etherden, „Review of probabilistic load flow approaches for power distribution systems with photovoltaic generation and electric vehicle charging,“ *Electrical Power and Energy Systems* 120, 2020.
- [12] J. Romero-Ruiz, J. P.-R. S. Martin, J. Aguado und S. D. I. Torre, „Probabilistic congestion management using EVs in a smart grid with intermittent renewable generation,“ *Electric Power Systems Research*, 2016.
- [13] A. Srivastava, D. Steen, L. A. Tuan und O. Carlson, „A Congestion Forecast Framework for Distribution Systems with High Penetration of PVs and PEVs,“ *2019 IEEE Milan Power Tech*, 2019.
- [14] D. Reinert, H. Frank, F. Prill, M. Dehnhard, M. Baldauf, C. Schraff, C. Gebhardt, C. Marsigli und G. Zängl, „DWD Database Reference for the Global and Regional ICON and ICON-EPS Forecasting System,“ Deutscher Wetterdienst, Offenbach am Main, 2023.
- [15] B. R. Prusty und D. Jena, „A critical review on probabilistic load flow studies in uncertainty constrained power systems with photovoltaic generation and a new approach,“ *Renewable and Sustainable Energy Reviews*, pp. 1286-1302, 2017.
- [16] Deutscher Wetterdienst, „Open Data Server,“ [Online]. Available: <https://opendata.dwd.de/>. [Zugriff am 24 Januar 2024].
- [17] T. Tjaden, J. Bergner, J. Weniger und V. Quaschnig, *Repräsentative elektrische Lastprofile für Wohngebäude in Deutschland auf 1-sekündiger Datenbasis*, [Datensatz] Hochschule für Technik und Wirtschaft (HTW) Berlin, Lizenz: CC-BY-NC-4.0, [Zugriff am 15 November 2023].
- [18] F. Braeuer, „Load profile data of 50 industrial plants in Germany for one year,“ 17 Juni 2020. [Datensatz]. Verfügbar unter: <https://zenodo.org/records/3899018>. [Zugriff am 15 November 2023].
- [19] VDEW, „Repräsentative VDEW-Lastprofile,“ Frankfurt (Main), 1999.
- [20] S. Meinecke, D. Sarajlic, S. R. Drauz, A. Klettke, L.-P. Lauen, C. Rehtanz, A. Moser und M. Braun, „SimBench - A Benchmark Dataset of Electric Power Systems to Compare Innovative Solutions based on Power Flow Analysis,“ *Energies*, Bd. 13, Nr. 12, Juni 2020.